

An optimized deep learning approach based on autoencoder network for P300 detection in brain computer interface systems

Ramin Afrah¹, Zahra Amini^{2*}, Rahele Kafieh², Alireza Vard²¹School of Advanced Technologies in Medicine, Isfahan University of Medical Sciences, Isfahan, Iran²Medical Image and Signal Processing Research Center, School of Advanced Technologies in Medicine, Isfahan University of Medical Sciences, Isfahan, Iran

ARTICLE INFO

Article History:

Received: 18 May 2022

Accepted: 13 Aug 2022

ePublished: 15 Oct 2022

Keywords:

- Artificial Intelligence
- P300
- Brain computer interface (BCI)
- Classification
- Deep learning

Abstract

Background. Brain computer interface (BCI) systems by extracting knowledge from brain signals provide a connection channel to the outside world for disabled people, without physiological interfaces. Event-related potentials (ERPs) are a specific type of electroencephalography signals and P300 is one of the most important ERP components. The critical part of P300-based BCI systems is classification step. In this research, an approach is proposed for P300 classification based on novel machine learning methods using convolutional neural networks (CNN) and autoencoder networks.

Methods. In the pre-processing step, channel selection, data augmentation (by ADASYN method), filtering and base-line drift were done. Then, in the classification step, four different CNN classifiers including CNN1D, CNN2D, CNN1D_Autoencoder, and CNN2D-Autoencoder were used for P300 classification.

Results. After implementation and tuning the networks, 92% as a best accuracy was achieved by CNN2D_Autoencoder. This result was achieved with a considerable tradeoff between complexity and stability.

Conclusion. The acquired results emphasize the ability of the deep learning methods in P300 classification and approve the advantage of using them in BCI systems. Furthermore, autoencoder versions of CNN networks are more stable and have a faster convergence. Meanwhile, ADASYN is a suitable method for augmentation of P300 data and even ERPs by sustaining the premier feature space without copying data.

Practical Implications. Our results can increase the accuracy of P300 detection and simultaneously reduce the volume of data using the proposed model. Consequently, they can improve character recognition in P300-speller systems generally used by amyotrophic lateral sclerosis (ALS) patients.

How to cite this article: Afrah R, Amini Z, Kafieh R, Vard A. An Optimized Deep Learning Approach Based on Self-Encoder Network for P300 Detection in Brain Computer Interface Systems. *Med J Tabriz Uni Med Sciences*. 2022;44(4):270-280. doi: 10.34172/mj.2022.033. Persian.

Extended Abstract

Background

Brain computer interface (BCI) systems by extracting knowledge from brain signals provide a

connection channel to the outside world for disabled people, without physiological interfaces. There are different types of brain signals. Because of the

*Corresponding author; Email: zahraamini64@gmail.com

© 2022 The Authors. This is an Open Access article published by Tabriz University of Medical Sciences under the terms of the Creative Commons Attribution CC BY 4.0 License (<http://creativecommons.org/licenses/by/4.0>), which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

portability and ease of signal acquisition, BCIs based on electroencephalography (EEG) signal are the most popular ones. Event related potentials (ERPs) are a specific type of EEG signals generated after a specific stimulation. The stimulation can be visual, audition, or based on touch. P300 is one of the most important ERP components. BCI speller is a type of BCI used for typing based on visual P300 component. BCI speller contains signal acquisition, pre-processing, signal classification, and finally application. The critical part of P300-based BCI systems is classification step. In this research, an approach is proposed for P300 classification based on unsupervised deep learning methods using convolutional neural networks (CNN) and autoencoder networks.

Methods

The proposed method includes preprocessing and classification. In the pre-processing step, channel selection based on the P300 structural features was done, so that for subject A, Fz, Cz, Pz, C3, C4, PO7, and PO8 and for subject B, Cz, C3, C2, F2, F8, and FC4 channels were selected. In the next step, data augmentation based on Adaptive Synthetic Sampling Approach (ADASYN) was considered. This method preserves the feature space as before, maintains structural formation of P300 signal; it also prohibits signal copying by synthetic approach, which prevents overfitting. Moreover, to improve signal to noise ratio (SNR), band pass Chebyshev filter with the cut off frequency of 0.1 to 20 Hz was applied. Then, to remove the DC part of the signal, base-line drift was done. Because of necessity of processing nonlinear data and thanks to noticeable improvement in hardware, deep learning methods were getting popular for processing medical data. In the case of neuroscience data processing, based on literature, CNN were the most used and popular methods among all types of deep learning models. To have a feasibility of reasonable comparison with other researches, BCI competition III dataset was selected. By applying supervised CNN methods on this dataset, we noticed that delay in convergence and instability during the training and validation process were two main shortcomings of the methods. To address these challenges, we employed CNN methods based on unsupervised learning. Afterward, in the classification

step, four different CNNs, including CNN1D, CNN2D, CNN1D_Autoencoder, and CNN2D_Autoencoder were used for P300 classification. Two parts of autoencoders are encoder and decoder; autoencoder receives the data at the first layer of encoder and reconstructs it at the last layer of decoder. During this process, the network learns how to abstract the data at the latent space which is fed to classifier.

Results

After implementation and tuning the networks, the results showed minimum fluctuation in accuracy and loss diagrams during training and validation process, which indicates more stability in autoencoder networks. Furthermore, autoencoders showed faster convergence compared to supervised approaches of CNN1D and CNN2D. By increasing the dimension of the data, the value of the evaluation metrics increased, but the complexity of the networks also increased drastically, which is a disadvantage for classifier. By applying unsupervised feature extraction methods based on autoencoder networks, we applied deep learning-based approach for classification of P300 with low computational complexity. We addressed this issue by abstract data through autoencoder network. In terms of sensitivity metric, autoencoder network showed better performance. In accuracy and precision metrics, networks with two-dimension input data illustrated higher scores in both groups of autoencoders and supervised networks. However, this superiority did not apply to the F1-Score criterion. In accuracy metric, 92%, in precision, 89%, in sensitivity 98%, and in F1-Score metric 94% acquired the best results. The results were achieved with a considerable tradeoff between complexity and stability in autoencoders, which is because of the advantages of unsupervised feature extraction based on autoencoders.

Conclusion

In this study we evaluated the performance of deep learning methods in EEG interpretation, especially P300 signal for use in BCI systems. The acquired results emphasized the ability of the deep learning methods in P300 classification and approved the advantage of using them in BCI systems.

Furthermore, autoencoder versions of CNN networks were more stable and had a faster convergence because of their ability in data abstraction. Because of the oddball nature of ERP signals, the classes of these types of signals are not balanced, leading to bias in classification. There are many data augmentation approaches, but two main weaknesses of these

methods include copying the data and randomness. The proposed ADASYN method is a suitable method for augmentation of P300 data and even other types of ERPs by sustaining the premier feature space and without copying data.

شناسایی مولفه P300 با استفاده از روش های یادگیری عمیق بدون سرپرست بر پایه شبکه خود رمزگذار به منظور استفاده در سیستم های واسط مغز و رایانه

رامین افراه^۱، زهرا امینی^۲، راحله کافیه^۲، علیرضا ورد^۲

^۱ دانشکده فناوری های نوین پزشکی، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران
^۲ مرکز تحقیقات پردازش تصویر و سیگنال پزشکی، دانشکده فناوری های نوین پزشکی، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران.

اطلاعات مقاله

سابقه مقاله:

دریافت: ۱۴۰۱/۲/۲۸
پذیرش: ۱۴۰۱/۵/۲۲
انتشار برخط: ۱۴۰۱/۷/۲۳

کلیدواژه ها:

- هوش مصنوعی
- مولفه P300
- سیستم های واسط مغز و رایانه
- طبقه بندی
- یادگیری عمیق

چکیده

زمینه. سیستم های واسط مغز و رایانه با استخراج اطلاعات از سیگنال های مغز، امکان ارتباط مغز با محیط، بدون استفاده از واسط فیزیولوژیک را فراهم می کنند. پتانسیل های وابسته به رخداد نوعی از سیگنال های مغزی هستند که P300 یکی از شاخه شده ترین مولفه ها در این دسته از سیگنال هاست. از مهم ترین بخش ها در طراحی سیستم های واسط مغز و رایانه مبتنی بر P300، طبقه بندی سیگنال دریافتی به دو دسته P300 و np300 است. در این مطالعه، رهیافتی بر پایه روش های یادگیری ماشین نوین به منظور طبقه بندی این مولفه ارائه شده است.

روش کار. در ابتدا کانال های مناسب انتخاب شدند، سپس دادگان با روش نمونه برداری سنتزی تطبیقی افزوده شده و فیلتر شدند و مقدار ثابت از سیگنال حذف شد. چهار شبکه کانولوشن یک بعدی، کانولوشن دو بعدی، شبکه خود رمزگذار کانولوشن یک بعدی و خود رمزگذار کانولوشن دو بعدی جهت طبقه بندی مولفه P300 پیشنهاد شده است.

یافته ها. پس از یافتن پارامترهای بهینه و منطبق بر ساختار داده، صحت ۹۲ درصد، به عنوان بیشترین صحت و با استفاده از مدل خود رمزگذار کانولوشن دو بعدی کسب شد که مصالحه ای مناسب بین بار محاسباتی، قابلیت تعمیم پذیری و ثبات در هنگام فرآیند آموزش و اعتبار سنجی دارد.

نتیجه گیری. نتایج به دست آمده حاکی از آن است که قابلیت های روش های یادگیری عمیق، آن ها را به ابزاری مناسب جهت طبقه بندی دادگان P300 تبدیل کرده که در نهایت باعث ارتقای عملکرد سیستم های واسط مغز و رایانه می شوند و در این میان روش های کانولوشنی خود رمزگذار ثبات بیشتر و همگرایی سریع تر نسبت به نسخه غیر خود رمزگذار در فرآیند آموزش و اعتبار سنجی دارند. علاوه بر این، روش ADASYN با حفظ ساختار اولیه فضای ویژگی و عدم کپی برداری از دادگان موجود، روشی مناسب برای برابری کلاس ها در طبقه بندی P300 است.

پیامدهای عملی. افزایش صحت شناسایی مولفه P300 و همچنین کاهش حجم داده به شکل موثر با استفاده از شبکه خود رمزگذار پیشنهادی و در نتیجه آن افزایش توانایی تشخیص کاراکتر در سیستم های اسپلر مورد استفاده بیماران فلج عصبی عضلانی.

مقدمه

سیستم های دروغ سنج، بازی های رایانه ای و ... نیز مورد استفاده قرار می گیرند.^۱ عملکرد سیستم های واسط مغز و رایانه به این صورت است که سیستم در ابتدا پس از دریافت سیگنال مغزی در ورودی، الگوی مشخصی را از سیگنال استخراج و طبقه بندی کرده و در نهایت بازخورد را به محیط برمی گرداند.^۲ از شناخته شده ترین انواع این سیستم ها، سیستم های مبتنی بر مولفه P300

افراد مبتلا به بیماری های عصبی-عضلانی، پتانسیل هایی از جنبه شناختی دارند که با وجود ناتوانایی آنها در انجام امور روزمره، امکان ارتباط با محیط پیرامون را برای آنها فراهم می کند.^۱ سیستم های واسط مغز و رایانه یا (Brain Computer Interface) BCI امکان ارتباط این افراد با محیط پیرامون را فراهم کرده و در زمینه های دیگر مانند تحقیقات شناختی، بازخورد سیستم اعصاب،

*نویسنده مسؤول: ایمیل: zahraamini64@gmail.com

حق تالیف برای مولفان محفوظ است. این مقاله با دسترسی آزاد توسط دانشگاه علوم پزشکی تبریز تحت مجوز کپی رایت کامنز 4.0 CC BY (http://creativecommons.org/licenses/by/4.0) منتشر شده که طبق مفاد آن هرگونه استفاده تنها در صورتی مجاز است که به اثر اصلی به نحو مقتضی استناد و ارجاع داده شده باشد.

در این مقاله از دادگان جهانی مربوط به مسابقات سیستم های واسط مغز و رایانه استفاده شده است. در اخذ این دادگان که از طریق ۶۴ کانال در استاندارد ۱۰-۲۰ ثبت شده، یک جدول با ابعاد ۶×۶ حاوی ۳۶ کاراکتر در مقابل فرد وجود دارد. هر آزمایش جهت تشخیص یک کاراکتر است. برای یک دور کامل از آزمایش، ۱۲ تحریک اتفاق می افتد که فقط دو مورد حاوی مولفه P300 هستند. این آزمایش برای هر کاراکتر ۱۵ مرتبه تکرار شده است، بنابراین برای هر کاراکتر ۳۰ سیگنال حاوی P300 و ۱۵۰ سیگنال فاقد آن (np300) موجود است. در این مطالعه به دادگان دو سوژه (Subject) و به طور کل به ۱۵۳۰۰ نمونه از هر سوژه دسترسی وجود داشت که ۲۵۵۰ عضو (قطعه) این مجموعه حاوی مولفه P300 و ۱۲۷۵۰ قطعه آن نیز فاقد مولفه P300 هستند.

روش پیشنهادی

بیش پردازش

داده از مسابقات سیستم های واسط مغز و رایانه سال ۲۰۰۵ اخذ شده، فرکانس ۲۴۰ هرتز بوده و داده از فیلتر میان گذر ۰/۱ تا ۶۰ هرتز عبور داده شده و آرتیفکتهای موجود قبل از تحویل به شرکت کنندگان حذف شده است. در ابتدا جهت انتخاب کانال های مناسب و کاهش حجم محاسبات، برای هر سوژه، تمام ۶۴ کانال بررسی شده و کانال هایی که حالت آناومیک آنها معرف بهتری برای مولفه P300 بوده و ۳۰۰ میلی ثانیه پس از تحریک دارای قله مثبت نسبت به کلاس np300 باشند به عنوان کانال مناسب انتخاب شدند. برای سوژه A، کانال های PO7، C4، C3، Pz، Cz، Fz انتخاب شدند. برای سوژه B، C3، Cz، F2، F8، FC4، T8 انتخاب شده اند. سپس جهت برقراری تعادل بین دادگان دو گروه، از روش داده افزایی (Augmentation) نمونه برداری سنتزی تطبیقی ADASYN^{۱۵} استفاده شده و با افزایش تعداد قطعه های کلاس با تعداد قطعات کمتر، تعداد قطعات دو کلاس برابر شده اند. دو معیار اصلی در انجام داده افزایی مورد توجه قرار گرفت. معیار اول، عدم کپی برداری از قطعه های موجود در دادگان و معیار دوم حفظ ساختار ویژگی دادگان اصلی در فضای ویژگی ها بود. با بررسی روش های مختلف، روش ADASYN به عنوان روش اصلی انتخاب شد. نتایج قبل و بعد از داده افزایی در شکل ۱ نمایش داده شده است. برای پیاده سازی قسمت های مختلف روش پیشنهادی در قالب روش های یادگیری عمیق از زبان پایتون نسخه ۳/۶ و از پردازنده Graphics Processing Unit (GPU) NVIDIA Tesla K80 استفاده شد.

است. P300 قله ای با دامنه مثبت است که حدود ۳۰۰ میلی ثانیه پس از اعمال تحریک در سیگنال مغزی الکتروانسفالوگرافی قابل مشاهده است.^۴ به طور کلی مطالعات انجام گرفته در زمینه طبقه بندی این مولفه را می توان در دو دسته روش های کلاسیک یادگیری ماشین و روش های نوین مبتنی بر یادگیری عمیق (Deep Learning) قرار داد.^۵ استخراج ویژگی و طبقه بندی، دو بخش اصلی تحقیقات بر پایه یادگیری ماشین کلاسیک هستند.^{۶-۸} اصلی ترین مشکل در این روش ها، میزان پایین سیگنال به نویز^۹ و عدم امکان تعامل با خواص غیر خطی دادگان هستند.^۸ با توجه به نیاز به پردازش دادگان با خاصیت غیرخطی، به تدریج استفاده از شبکه های عصبی جهت طبقه بندی سیگنال های مغزی نیز افزایش یافت^{۱۰} و در سال های اخیر با پیشرفت های سخت افزاری، این روش ها محبوبیت روزافزونی در حوزه طبقه بندی مولفه P300 پیدا کرده اند. با توجه به نیاز به مدل هایی جهت پردازش دادگان با پیچیدگی بیشتر، بر آن شدیم تا با استفاده از شبکه های یادگیری عمیق به پردازش دادگان P300 پردازیم، در عین حال با توجه به حجم بالای دادگان، پیچیدگی محاسباتی بالا و عدم پایداری مطلوب شبکه های یادگیری عمیق مبتنی بر سرپرست در فرآیند طبقه بندی، تلاش کردیم تا به کمک رهیافت شبکه های بدون سرپرست و با خلاصه سازی داده ها به شکل بهینه، حجم محاسباتی را کاهش داده و به پایداری مورد نظر در فرآیند آموزش شبکه نزدیک تر شویم.^{۱۲} در ادامه^{۱۳} به بررسی انواع روش های یادگیری عمیق مورد استفاده در تحلیل سیگنال EEG پرداخته شده که براساس این مطالعه، شبکه های عصبی کانولوشنی عمیق^{۱۴} خود رمز گذارها (Autoencoders) به عنوان پراستفاده ترین شبکه ها در تحلیل سیگنال الکتروانسفالوگرافی مورد توجه قرار گرفته اند. از مزایای این روش ها می توان به خاصیت استخراج ویژگی به صورت خودکار، چکیده کردن داده و عملکرد برتر نسبت به روش های کلاسیک یادگیری ماشین در مواجهه با دادگان غیرخطی اشاره کرد.^۸ در ادامه، به معرفی دادگان و روش های پیشنهادی، سپس یافته ها و در آخر به بحث درباره یافته ها می پردازیم.

روش کار

در این قسمت در راستای یک پژوهش اصیل در ابتدا به شرح دادگان و سپس به بیان روش های به کار گرفته شده می پردازیم.

دادگان

از جمله مشکلات در مقایسه عملکرد گروه های پژوهشی مختلف در این زمینه، استفاده آنها از دادگان متنوع است. بنابراین


نسخه بدون سرپرست (Unsupervised) این شبکه‌ها در قالب نسخه خود رمزگذار بررسی شود. بدین ترتیب در این پژوهش از ۴ شبکه زیر برای طبقه بندی دادگان P300 استفاده شد: ۱- شبکه عصبی کانولوشن عمیق یک بعدی ۲- شبکه عصبی کانولوشن عمیق دو بعدی ۳- شبکه کانولوشن یک بعدی خود رمزگذار ۴- شبکه کانولوشن دو بعدی خود رمزگذار. معماری هر یک از ۴ شبکه پیشنهادی در شکل ۲ نشان داده شده است.

در کانولوشن یک بعدی خود رمزگذار خروجی یک ماتریس ویژگی با ابعاد (۸۴×۱۶) و در کانولوشن دو بعدی خود رمزگذار خروجی ماتریسی ابعاد (۴×۱۲۰×۱۶) است که پس از تبدیل آن به یک بردار ویژگی آن را به یک طبقه‌بند شبکه عصبی (طبق شکل ۲-۵) می‌دهیم.


پس از انجام داده‌افزایی با توجه به حضور مولفه های فرکانس پایین در مولفه P300 جهت پیش پردازش بهتر، از فیلتر چبیشف (Chebyshev) میان‌گذر با فرکانس قطع ۱/۰ تا ۲۰ هرتز استفاده شد. جهت طبیعی‌سازی داده در آخر مقدار پایه (Base Line Drift) از سیگنال حذف شد.

طبقه بندی

با توجه به مطالعات پیشین، شبکه عصبی کانولوشن عمیق یک بعدی و دو بعدی، به عنوان دو روش کارآمد در تحلیل سیگنال EEG مورد توجه قرار گرفتند. با توجه به با سرپرست (Supervised) بودن روش یادگیری در این شبکه‌ها و همچنین تاخیر در همگرایی و عدم پایداری در حین فرآیند آموزش و اعتبار سنجی بر روی دادگان مسابقات، در این مقاله تلاش شده است تا




الف- مقایسه ساختار مولفه P300، قبل (آبی) و بعد (نارنجی) از داده‌افزایی به روش ADASYN




ب- توزیع دادگان کلاس P300 قبل (آبی) و بعد (نارنجی) از داده‌افزایی


شکل ۱. تأثیر داده‌افزایی به روش ADASYN بر دادگان کلاس با تعداد کمتر




الف




ب




ج



د



شکل ۲. الف- معماری شبکه کانولوشن یک بعدی، ب- معماری شبکه کانولوشن دو بعدی، ج- معماری شبکه کانولوشن یک بعدی خود رمزگذار، د- معماری شبکه کانولوشن دو بعدی خود رمزگذار، ه- معماری طبقه‌بند مورد استفاده در شبکه‌های خود رمزگذار



شکل ۳. الف- نمودار صحت سوز A، ب- نمودار هزینه سوز A، پ- نمودار صحت سوز B، ت- نمودار هزینه سوز B

جدول ۱. نتایج شبکه‌های پیاده شده در سوز A (الف) و در سوز B (ب)

تعداد اپوک	معیار F1	حساسیت	دقت	صحت	الف
۳۰۰	۸۷٪	۹۲٪	۸۴٪	۹۱٪	کانولوشن یک بعدی
۳۰۰	۹۰٪	۹۴٪	۸۷٪	۹۲٪	کانولوشن دو بعدی
۸۰	۹۴٪	۹۸٪	۸۹٪	۹۲٪	کانولوشن یک بعدی خود رمزگذار
۱۰۰	۸۸٪	۹۸٪	۸۱٪	۹۲٪	کانولوشن دو بعدی خود رمزگذار

ب

تعداد اپوک	معیار F1	حساسیت	دقت	صحت	
۳۰۰	۸۷%	۹۱%	۸۴%	۹۰%	کانولوشن یک بعدی
۳۰۰	۸۸%	۹۲%	۸۶%	۹۱%	کانولوشن دو بعدی
۸۰	۹۱%	۹۸%	۸۳%	۹۰%	کانولوشن یک بعدی خود رمزگذار
۱۰۰	۸۹%	۹۸%	۸۲%	۹۲%	کانولوشن دو بعدی خود رمزگذار

$$\text{رابطه (۱)} = \frac{\text{منفی واقعی} + \text{مثبت واقعی}}{\text{همه داده ها}} = \text{صحت}$$

$$\text{رابطه (۲)} = \frac{\text{مثبت واقعی}}{\text{مثبت کاذب} + \text{مثبت واقعی}} = \text{دقت}$$

$$\text{رابطه (۳)} = \frac{\text{مثبت واقعی}}{\text{منفی کاذب} + \text{مثبت واقعی}} = \text{حساسیت}$$

$$\text{رابطه (۴)} = \frac{\text{حساسیت} \times \text{دقت} \times 2}{\text{حساسیت} + \text{دقت}} = \text{معیار } F$$

یافته ها

نتایج حاصل از پیاده سازی ۴ روش پیشنهادی در جدول ۱ قابل مشاهده است. نتایج نشان دهنده پایداری بیشتر (نوسان کمتر در نمودار هزینه و صحت) شبکه های مبتنی بر خود رمزگذار در مقایسه با روش های غیر خود رمزگذار همان شبکه ها هستند. همچنین شبکه های مبتنی بر خود رمزگذار سریع تر (با تعداد اپوک کمتر) از شبکه های غیر خود رمزگذار همگرا می شوند. با افزایش بعد داده، میزان پیچیدگی محاسباتی نیز افزایش پیدا کرده و به دنبال آن، به طور نسبی میزان صحت نیز افزایش پیدا می کند. در معیار حساسیت، شبکه های مبتنی بر خود رمزگذار در مقایسه با روش های غیر خود رمزگذار عملکرد بهتری داشته اند. نتایج در قالب معیارهای زیر بررسی شدند: در معیارهای صحت، دقت و حساسیت شبکه ها با ورودی دو بعدی نتایج بهتری را نسبت به شبکه با ورودی داده یک بعدی داشتند اما این برتری در معیار F1 صدق نمی کند. در معیار صحت، بهترین درصد کسب شده ۹۲ درصد، در معیار دقت ۸۹ درصد، در معیار حساسیت ۹۸ درصد و در معیار F1 ۹۴ درصد بودند.

بحث

در این پژوهش با هدف طراحی یک سیستم آشکارساز مولفه P300 مبتنی بر روش های یادگیری عمیق، همراه با کاهش بعد داده جهت کاهش پیچیدگی محاسباتی فرآیند طبقه بندی و استفاده از مولفه های اصلی داده جهت افزایش سرعت همگرایی طبقه بند و افزایش پایداری در فرآیند آموزش و اعتبارسنجی بخش های مختلف کار بررسی شد. به این جهت سیستم پیشنهادی

معرفی و پیاده سازی شده و جزییات و کارایی آن نیز به شکل گسترده بررسی شد. مدل پیشنهادی جهت طبقه بندی مولفه P300 شامل بلوک های داده افزایی، انتخاب کانال، پیش پردازش، طبقه بندی و ارزیابی است. فراگیری بررسی دادگان استفاده شده در این مطالعه و مهیا شدن امکان مقایسه نتایج کسب شده با نتایج دیگر مطالعات از مهم ترین دلایل استفاده از این دادگان بوده اما با توجه محدودیت تعداد سوژه های استفاده شده در این دادگان، در مطالعه جاری امکان بررسی قابلیت تعمیم پذیری مدل موجود نیست. در بین روش های پیشنهادی، مدل کانولوشن دو بعدی خود رمزگذار با توجه به امکان تعریف کرنل دو بعدی در بخش کانولوشن و در نتیجه امکان استخراج دو مولفه اصلی زمان و مکان به صورت همزمان، در مقابل شبکه کانولوشن یک بعدی خود رمزگذار و کانولوشن یک بعدی که فقط امکان تعریف کرنل یک بعدی در بخش کانولوشن آن ها وجود دارد، عملکرد بهتری داشت و همچنین با استفاده از بازسازی سیگنال داده شده به شبکه در انتهای بخش رمزگشای شبکه خود رمزگذار و امکان بهره مندی از قابلیت یادگیری خود سرپرست یا بدون سرپرست نسبت به شبکه کانولوشن دو بعدی عملکرد بهتری داشت. این شبکه توانست با دستیابی به صحت ۹۲ درصد به نتیجه قابل قبولی در طبقه بندی دادگان P300 دست یابد. در ^۱ برای سوژه A صحت ۷۵ درصد و در سوژه B صحت ۷۸ درصد کسب شده است. در ^{۱۷} برای سوژه A صحت ۸۲ درصد و برای سوژه B صحت ۸۶ درصد کسب شده است. در ^{۱۸} برای سوژه A صحت ۸۴ درصد و برای سوژه B صحت ۸۶ درصد کسب شده است. در ^{۱۹} صحت کسب شده برای طبقه بندی مولفه P300 در سوژه A، ۸۱/۲ درصد

مشارکت پدیدآوران

رامین افراه جمع‌آوری دادگان، پیاده سازی روش پیشنهادی، تحلیل و تفسیر داده ها و تهیه پیش نویس، زهرا امینی ایده پردازی، طراحی اثر، تفسیر نتایج، مرور و نقد پیش‌نویس و بررسی از جهت محتوای فکری، راحله کافیه ایده پردازی، طراحی اثر و تفسیر نتایج و علیرضا ورد ایده پردازی، نقد پیش‌نویس و بررسی از جهت محتوای فکری را عهده داشتند.

منابع مالی

قسمتی از منابع مالی این مقاله از طریق طرح مصوب با عنوان "آشکارسازی مولفه P300 با استفاده از روش های یادگیری عمیق به منظور استفاده در سیستم های واسط مغز و رایانه " و به شماره طرح ۳۹۸۴۲۸ و با حمایت معاونت تحقیقات و فناوری دانشگاه علوم پزشکی اصفهان تامین شده است.

دسترسی پذیری داده ها

دادگان مطالعه فعلی در پایگاه [\[https://www.bbc.de/competition/iii/\]](https://www.bbc.de/competition/iii/) موجود است.

ملاحظات اخلاقی

این مقاله حاصل از طرح با عنوان "آشکارسازی مولفه P300 در سیگنال EEG با استفاده از روش‌های یادگیری عمیق جهت کاربرد در سیستم های واسط مغز و رایانه" است که طرح بالا در معاونت تحقیقات و فناوری دانشگاه علوم پزشکی اصفهان بررسی و با شناسه اخلاق IR.MUI.RESEARCH.REC.1398.337 مصوب گردید.

تعارض منافع

پدیدآوران اعلام می‌کنند که این اثر حاصل یک پژوهش مستقل بوده و هیچگونه تضاد منافی با سازمان‌ها و اشخاص دیگری ندارد.

و برای سوژه B، ۸۴/۲ درصد کسب شده است. این نتایج برتری نتایج کسب شده در پژوهش اخیر را نشان می‌دهند. علاوه بر صحت در طبقه بندی مولفه P300، از نظر بار محاسباتی و پایداری شبکه نیز نتایج برتری کسب شده است. در نتیجه، با افزایش صحت شناسایی مولفه P300، کاهش حجم داده به شکل موثر با استفاده از شبکه خود رمزگذار و به دنبال آن افزایش کیفیت تشخیص کاراکتر در سیستم‌های اسپلر مورد استفاده بیماران فلج عصبی عضلانی و تمامی سیستم های مبتنی بر P300، این مطالعه می‌تواند گامی در راستای بهبود عملکرد سیستم های واسط مغز و رایانه مبتنی بر P300 باشد. نمودار هزینه و صحت شبکه منتخب در شکل ۳ نمایش داده شده است.

نتیجه گیری

با توجه به هدف مطالعه مبنی بر انجام فرآیند طبقه‌بندی با کیفیت بالا روی دادگان ذکر شده در این مطالعه، به بررسی دادگان دیگر در این مطالعه پرداخته نشده و این موضوع به مطالعات آتی موکول شده است. در بحث داده‌افزایی معیارهای عدم کپی برداری از دادگان اصلی و همچنین حفظ توزیع دادگان در فضای ویژگی ها دو معیار مناسب جهت انتخاب روش داده افزایی هستند و روش ADASYN با داشتن این دو ویژگی عملکرد مناسبی را در داده‌افزایی نمایش می‌دهد. با استفاده از روش های خود رمزگذار مولفه‌های اصلی داده استخراج شده و در نتیجه میزان پایداری در فرآیند آموزش و سرعت همگرایی شبکه عصبی مصنوعی افزایش یافته و در نتیجه، کیفیت طبقه بندی نیز افزایش پیدا کرده است. با توجه به عدم توازن دو کلاس P300 و nP300 مطالعه بیشتر در زمینه داده‌افزایی پیشنهاد می‌شود. با افزایش بار محاسباتی در روش ها یادگیری عمیق به مراتب کیفیت طبقه بندی نیز افزایش پیدا می‌کند، برای کاهش بار محاسباتی و حفظ کیفیت طبقه‌بندی، مطالعات بیشتر در زمینه انتخاب کانال مناسب برای کاهش تعداد کانال ها و به دنبال آن کاهش بار محاسباتی پیشنهاد می‌شود.

References

1. Liu M, Wu W, Gu Z, Yu Z, Qi F, Li Y. Deep learning based on batch normalization for P300 signal detection. *Neurocomputing*. 2018;275:288-97. doi: 10.1016/j.neucom.2017.08.039
2. Agrawal P, Khanna P, Beulah Soundarabai P, Joseph NP. Electroencephalogram based Brain Computer Interface System Analysis. *IJITEE*, ISSN.2278-3075.
3. Gao Q, Dou L, Belkacem AN, Chen C. Noninvasive Electroencephalogram Based Control of a Robotic Arm for Writing Task Using Hybrid BCI System. *Biomed Res Int*. 2017;2017. Article ID 8316485. doi: 10.1155/2017/8316485
4. Kshirsagar GB, Londhe ND. "Deep convolutional neural network based character detection in devanagari script input based P300 speller," 2017 International Conference on Electrical, Electronics,

- Communication, Computer, and Optimization Techniques (ICEECOT). 2017;1:507-11. doi: 10.1109/ic_eccot.2017.8284557
5. Amini Z, Abootalebi V, Sadeghi MT. Comparison of performance of different feature extraction methods in detection of P300. *Biocybern Biomed Eng.* 2013;33(1):3-20. doi: 10.1016/s0208-5216(13)70052-4
 6. Aggarwal S, Chugh N. Review of machine learning techniques for EEG based brain computer interface. *Archives of Computational Methods in Engineering.* 2022;7:1-20.
 7. Turnip A, Hong KS. Classifying mental activities from EEG-P300 signals using adaptive neural network. *Int. J. Innov. Comp. Inf. Control.* 2012;8(7):5839-50.
 8. Roy Y, Banville H, Albuquerque I, Gramfort A, Falk TH, Faubert J. Deep learning-based electroencephalography analysis: a systematic review. *Journal of neural engineering.* 2019;16(5):051001. doi: 10.1088/1741-2552/ab260c
 9. Hoffmann U, Garcia G, Vesin JM, Diserens K, Ebrahimi T. A boosting approach to P300 detection with application to brain-computer interfaces. In *Conference Proceedings. 2nd International IEEE EMBS Conference on Neural Engineering*, 2005. 2005;6:97-100. doi: 10.1109/cne.2005.1419562
 10. Sagar AS, Salehen T, Rob MA. Drowsiness detection using combined neuroimaging: Overview and Challenges. *arXiv preprint arXiv.* 2022;13344:58-65.
 11. Mousavinasr SM, Pourmohammad A. An Improvement to Emotion Detection in EEG Signals Using Deep Artificial Neural Networks. *Medical Journal of Tabriz University of Medical Sciences.* 2018;40(5):91-101.
 12. Kieu T, Yang B, Guo C, Jensen CS, Zhao Y, Huang F, et al. Robust and explainable autoencoders for time series outlier detection. In *Proceeding of the 38th IEEE International Conference on Data Engineering, ICDE 2022.* 2022.
 13. O'Shea K, Nash R. An Introduction to Convolutional Neural Networks. 2015;26:1-11. Available from: <http://arxiv.org/abs/1511.08458>
 14. Le QV. A tutorial on deep learning part 2: Autoencoders, convolutional neural networks and recurrent neural networks. *Google Brain.* 2015;20:1-20.
 15. Hossin M, Sulaiman MN. A review on evaluation metrics for data classification evaluations. *International Journal of Data Mining & Knowledge Management Process.* 2015;5(2):1.
 16. He H, Bai Y, Garcia EA, Li S. ADASYN: Adaptive synthetic sampling approach for imbalanced learning. In *IEEE International Joint Conference on Neural Networks. IJCNN 2008(IEEE World Congr Comput Intell.* 2008;(3):1322-8. doi: 10.1109/ijcnn.2008.4633969
 17. Lu Z, Gao N, Liu Y, Li Q. The Detection of P300 Potential Based on Deep Belief Network. *Proc - 2018 11th Int Congr Image Signal Process. Biomed Eng Informatics, CISP-BMEI 2018.* 2019;1-5. doi: 10.1109/cisp-bmei.2018.8633147
 18. Shan H, Liu Y, Stefanov T. A simple convolutional neural network for accurate P300 detection and character spelling in brain computer interface. *IJCAI Int Jt Conf Artif Intell.* 2018;20:1604-10. doi: 10.24963/ijcai.2018/222
 19. Ghazikhani H, Rouhani M. A deep neural network classifier for P300 BCI speller based on Cohen's classtime-frequency distribution. *Turkish Journal of Electrical Engineering and Computer Sciences.* 2021;29(2):1226-40.